

Pregledni rad

UDK: 336:338.2(4-11)

Lucija Rogić, dipl. oec.

Dr. sc. Željko Bogdan

## UTJECAJ FINANCIJSKE INTEGRACIJE NA GOSPODARSKI RAST POSTTRANZICIJSKIH ZEMALJA

## THE IMPACT OF FINANCIAL INTEGRATION ON ECONOMIC GROWTH OF POSTTRANSITIONAL COUNTRIES

---

**SAŽETAK:** Razina kapitala u promatranim zemljama bila je zastarjela na početku tranzicijskoga procesa, te su bila potrebna ulaganja u fizički i ljudski kapital kako bi se postigao gospodarski rast, što je zahtijevalo pristup svjetskim financijskim tijekovima. Zbog toga je u radu provedena analiza utjecaja financijske integracije na gospodarski rast posttranzicijskih zemalja u razdoblju od 1990. do 2007. godine. Primjenom panel analize testirana je pretpostavka da veća financijska integracija pridonosi gospodarskom rastu posttranzicijskih zemalja. Utjecaj financijske integracije na gospodarski rast pokazao se negativnim, ali ne i statistički značajnim. Dinamička panel analiza pokazala je da statistički značajnu ulogu na gospodarski rast imaju državna potrošnja i otvorenost gospodarstva.

**KLJUČNE RIJEČI:** financijska integracija, tranzicija, gospodarski rast, panel analiza.

**ABSTRACT:** At the beginning of the transition processes in the analysed countries the level of physical capital was obsolete and investments in physical and human capital were required in order to achieve economic growth, which called for access to world financial flows. The paper includes the analysis of the influence of financial integration on economic growth of post-transition countries between 1990 and 2007. A hypothesis that greater financial integration stimulates economic growth of post-transition countries has been tested using panel data analysis. The influence of financial integration on growth proved to be negative, but statistically insignificant. However, the dynamic panel analysis has shown that government consumption and economic openness play a statistically significant role in economic growth.

**KEY WORDS:** Financial integration, transition, economic growth, panel analysis.

---

## 1. UVODNE NAPOMENE

Posljednjih dvadesetak godina obilježava porast stupnja ekonomske integriranosti, što se najviše odražava u međunarodnim tokovima trgovine, kapitala, investicija i migracija. Rastući obujam financijskih transakcija pridonio je integriranju financijskih tržišta i postao je središnjom temom istraživanja mnogih ekonomista. Ključni faktor je porast globalizacije investicija, što ima za posljedicu povećanje stope povrata, i veće mogućnosti da se rizik diversificira i na međunarodnoj razini. Istovremeno, tokovi kapitala su se liberalizirali u mnogim zemljama kroz deregulaciju domaćeg financijskog tržišta, liberalizaciju ograničenja na strana ulaganja, poboljšanje ekonomskog okruženja i provođenje tržišno orijentiranih reformi. Arfaoui i Abaoub (2010.) su pokazali da su svjetska kamatna stopa, svjetska ekonomska situacija i globalne mogućnosti rasta primarno određujući faktor prekograničnih kretanja financijskih sredstava, ali važnost imaju i socioekonomska stabilnost, tržišna otvorenost, lokalne investicije, proračunski višak, financijski razvoj i mogućnosti gospodarskog rasta. Vo i Daly (2007.) razlike u stupnju financijske integracije objašnjavaju manjim kapitalnim kontrolama, trgovinskom otvorenošću, domaćim kreditima i gospodarskim rastom.

U radu je središnji cilj istražiti utjecaj financijske integracije na gospodarski rast u post-tranzicijskim zemljama. Te zemlje su suočene s manjkom fizičkog i ljudskog kapitala, te su posezale za financijskim sredstvima iz inozemstva kako bi povećale fizički (a i ljudski kapital) jer je predtranzicijska razina fizičkog kapitala bila zastarjela (Gardó, Martin, 2010.). Prema standardnim makroekonomskim modelima porast obiju ovih varijabli pridonosi gospodarskom rastu, pa se zato ovdje testira hipoteza da *veća financijska integracija pridonosi gospodarskom rastu posttranzicijskih zemalja*. Dio ovih zemalja su već postale članice Europske unije, a dio je u statusu kandidata (Hrvatska, Makedonija), što im omogućuje da izvuku koristi iz integracijskog procesa. Analiza će obuhvatiti posttranzicijske zemlje srednje i jugoistočne Europe, te zemlje slijednice bivšeg SSSR-a.

Dosadašnja istraživanja utjecaja financijske integracije na gospodarski rast posttranzicijskih zemalja su uglavnom usredotočena na utjecaj stranih direktnih investicija (FDI) na gospodarski rast (Mencinger, 2003; Bačić, Račić, Ahec–Šonje, 2004; Asteriou, Dassiou, Glycopantis, 2005; Šimurina, 2006; Apergis, Lyroudi, Vamvakidis, 2008.) i zaključci se razlikuju. Za razliku od spomenutih radova, indikator financijske integracije koji će se koristiti u ovom radu u sebi će sadržavati i portfolio ulaganja.

Rad je koncipiran na način da se u drugom dijelu najprije definiraju financijska integracija i globalizacija, a potom slijede i njihovi indikatori. U trećem dijelu su objašnjeni kanali preko kojih financijska integracija može utjecati na rast. Četvrti dio sadrži pregled empirijske literature o vezi financijske integracije i gospodarskog rasta. Potom slijedi vlastito empirijsko istraživanje u petom dijelu, a šesti dio je zaključak.

## 2. DEFINICIJA, KORISTI I INDIKATORI FINANCIJSKE INTEGRACIJE

Premda se kod nekih autora poistovjećuju termini financijske integracije i financijske globalizacije, Prasad, Rogoff, Wei i Kose (2003.) ih jasno razlikuju, ali upućuju na veliku povezanost među njima. Prema ovim autorima, pod terminom financijska integracija se

podrazumijevaju veze pojedine zemlje s međunarodnim tržištima kapitala dok se pod terminom financijska globalizacija podrazumijeva povećanje globalnih veza koje se kreiraju kroz prekogranične financijske tokove.

Financijska integracija može rezultirati brojnim koristima. Kao najvažnija korist, koju donosi financijska integriranost, ističe se utjecaj financijske integracije na gospodarski rast, čemu je i posvećen cijeli članak. Ukratko će se navesti i ostale koristi do kojih može doći uslijed financijske integriranosti.

Jedna od očitih koristi je tzv. zaglađivanje potrošnje (eng. *consumption smoothing*). Naime, pristup svjetskom tržištu kapitala omogućava zemlji da pozajmljuje u „lošim“ vremenima, i daje u „dobrim“ vremenima. Kroz omogućavanje domaćinstvima da izgode svoju putanju potrošnje kroz vrijeme, tokovi kapitala mogu povećati blagostanje. Ovo se pokazalo važnim u trenucima kada su šokovi privremene naravi (Agénor, 2003.).

Još jedna korist od porasta financijske integracije se očituje u povećanoj efikasnosti bakarskog sustava i financijske stabilnosti (Agénor, 2003.). Do sličnih rezultata su došli i Klein i Olivei (2008.) ustvrdivši da je s većim stupnjem financijske integracije i veći stupanj razvoja financijskog sustava u odnosu na situaciju kada postoje kapitalne kontrole. Neki autori (Arribas, Pérez, Tortosa-Ausina, 2009.) navode da su određena tržišta komercijalnih banaka daleko od globaliziranog, te da stoga granice i udaljenosti i dalje igraju značajnu ulogu kod onih koji alociraju svoje resurse.

Financijska integracija u prvom redu može pridonijeti većem stupnju razvoja financijskog sustava jer može umanjiti problem asimetričnih informacija i povećavajući raspoloživost sredstava (Schmukler, 2004.). Naime, ako financijsko tržište dobro funkcionira, tada se ekonomskim agentima otvara mogućnost povećanja sredstava (za posuđivanje), i investiranja. No, financijski sustavi rijetko funkcioniraju poželjno jer su ekonomski agenti suočeni s problemom asimetričnih informacija (Agénor, 2003.). Problem asimetričnih informacija se odnosi na različitu količinu informacija raspoloživih agentu i principalu<sup>1</sup>. Postojanje asimetričnih informacija uzrokuje nepoželjan izbor i moralni hazard. Takva situacija prema mnogim ekonomistima (Stiglitz, Weiss, 1981.) vodi kreditnom racioniranju, jer zajmodavci nisu voljni odobriti kredite čak ni pri visokim kamatnim stopama.

Jedna od koristi financijske globalizacije jest i mogućnost diversifikacije rizika na međunarodnoj razini (Agénor, 2003.).

Da bi se uopće moglo istraživati determinante i učinke financijske integracije, potrebno je navesti i objasniti indikatore financijske integriranosti. U istraživanju efekata financijske integriranosti autori se često služe mjerama financijske otvorenosti koje se mogu podijeliti na *de facto* i *de iure* mjere financijske integracije (Arribas, Pérez, Tortosa-Ausina, 2009.).

*De iure* mjerenje se smatra tradicionalnim pristupom mjerenja financijske otvorenosti koji se zasniva na mjerenju legalnih ograničenja na međunarodne tokove kapitala. MMF-ov godišnji izvještaj AREAER (*Annual Report on Exchange Arrangements and Exchange Restrictions*) mjeri čak 60 različitih vrsta regulacija. Jedan od glavnih nedostataka ovakvog mjerenja je taj što se odnosi samo na kratki rok, ne uzimajući u obzir vrijeme i u skladu s tim

<sup>1</sup> O problemu principala i agenta, te nepoželjnog izbora i moralnog hazarda moguće je više vidjeti u svakom udžbeniku koji se bavi problematikom asimetričnih informacija (Mishkin, 2004; Acocella, 2005.).

samu promjenu kapitalnih kontrola (u terminima efikasnosti provođenja takvih regulacija). Također, neke od regulacija (poput ograničavanja tečajne izloženosti domaćih banaka) djeluju kao kontrole, iako se takvim ne smatraju u AREAER-u. U konačnici, može se reći kako *de iure* mjere ne odražavaju trenutni stupanj integracije ekonomije s međunarodnim tokovima kapitala (Kose, Prasad, Rogoff, Wei, 2009., str. 12. - 16.).

Alternativni pristup mjerenju financijske integracije su *de facto* mjere koje se razlikuju u dva pristupa pri čemu je jedan zasnovan na cijenama, a drugi na količinama (Kose, Prasad, Rogoff, Wei, 2009.). *De facto* mjerenje zasnovano na cijenama polazi od toga da integracija tržišta kapitala treba biti reflektirana u zajedničkim cijenama sličnih financijskih instrumenata preko nacionalnih granica. Nedostatak ovakvog pristupa je praktične prirode kada se mjerenje vrši za niskodohodovne zemlje. Također, domaće financijsko tržište može jednostavno biti nedovoljno likvidno da bi dozvolilo efikasnu arbitražu cijena. Stoga se kao najbolje mjere financijske integracije smatraju *de facto* mjere temeljene na količinama, te su zato i primjenjivane u ovom radu<sup>2</sup>. Lane i Milesi-Ferretti (2007.) i Lane i Milesi-Ferretti (2009.) su konstruirali takve mjere za 178 zemalja, te euro područje u razdoblju od 1970. do 2007. godine i u svoju bazu podataka uključili informacije o FDI-ju, portfolio vlasničkim investicijama, vanjskom dugu i inozemnim rezervama. O njihovim indikatorima će više riječi biti u empirijskom dijelu rada.

Unatoč tome što se *de facto* mjere preferiraju u odnosu na *de iure*, i jedne i druge sadržavaju bitne informacije o financijskoj integraciji, no *de facto* mjere pružaju bolju sliku o stupnju integracije zemlje unutar globalnih financijskih tržišta i za mnoga empirijska istraživanja, *de facto* mjere se smatraju prikladnijima (Kose, Prasad, Rogoff, Wei, 2009.), ali im se nedostatkom smatra moguća endogenost, što dovodi do problema uzročnosti (Collins, 2007.). Međutim, (Kose, Prasad, Rogoff, Wei, 2009.) drže da problem endogenosti nije stran ni *de iure* mjerama što ih, uz njihove ostale nedostatke, čini manje prihvatljivijim indikatorima financijske integracije u odnosu na *de facto* pokazatelje.

### 3. KANALI UTJECAJA FINANCIJSKE INTEGRACIJE NA GOSPODARSKI RAST

U radu je središnji cilj istražiti utjecaj financijske integracije na gospodarski rast u post-tranzicijskim zemljama. Zato je prije samog empirijskog istraživanja potrebno analizirati kanale utjecaja financijske integracije na ekonomsku aktivnost.

Jedan od najpoznatijih modela rasta, neoklasični, implicira da financijska integracija vodi kapitalnim priljevima od ekonomija bogatih kapitalom, prema ekonomijama gdje je kapital relativno oskudan. Na taj način financijski tokovi nadomještaju ograničenu domaću štednju u zemljama siromašnim kapitalom, snižavajući na taj način trošak kapitala

<sup>2</sup> *De facto* mjere financijske integracije mogu se iskazati kao neto ili bruto tokovi kapitala, pa ostaje upitno treba li koristiti neto ili bruto tokove, što ovisi o području interesa istraživača. Bruto tokovi su prikladniji instrument jer pokazuju manju volatilnost i opipljiviju sliku integracije. Međutim, unatoč smanjenoj volatilnosti u odnosu na neto tokove, godišnji bruto tokovi su i sami volatilni i skloni greškama u mjerenju. Da bi se izbjegli navedeni problemi, preferira se korištenje udjela sume bruto stranih potraživanja i obveza u bruto domaćem proizvodu.

stimulirajući investicije. No, u stvarnosti model se često smatra naivnim jer je stvarni volumen toka kapitala u siromašnije zemlje manji od onog kojeg predviđa neoklasični model. Ta situacija se u ekonomskoj literaturi naziva Lucasov (1990.) paradoks kojeg potvrđuju Alfaro, Kalemli-Özcan, Volosovich (2007. i 2008.).

Kanali preko kojih međunarodna financijska integracija može utjecati na gospodarski rast mogu se podijeliti u dvije skupine: direktne i indirektne kanale (Prasad, Rogoff, Wei, Kose, 2003.).

U direktne kanale ubraja se porast domaće štednje. Kao što se već spomenulo u radu, financijska integracija povećava investicije u zemljama siromašnim kapitalom, a samim time i povrat na iste u odnosu na situaciju u zemljama bogatim kapitalom dok smanjivanje rizika u zemljama s manje kapitala, kao posljedica toga, vodi povećanju štednje. Drugi direktni kanal je smanjivanje troška kapitala. Naime, međunarodna financijska integracija vodi većoj diversifikaciji rizika i boljoj alokaciji resursa, uslijed čega se smanjuje trošak kapitala. Prijenos tehnologije se također ubraja u direktne kanale. Financijski integrirane ekonomije privlače veliki priljev neto stranih investicija, koje mogu generirati tehnološka prelijevanja, što može pridonijeti boljem korporativnom upravljanju i većem gospodarskom rastu. Tehnološka prelijevanja također mogu podići agregatnu produktivnost, a samim time i gospodarski rast. Posljednji direktni kanal je razvoj financijskog sustava koji djeluje preko povećane likvidnosti kako je već objašnjeno u članku.

Nasuprot spomenutim kanalima, promocija specijalizacije, povod za boljim politikama i poboljšanje kapitalnih priljeva zbog signaliziranja boljih politika spadaju u indirektne kanale. Teza da specijalizacija u proizvodnji može povećati produktivnost i rast je opće poznata. Međutim, visoko specijalizirana proizvodnja može povećati volatilnost domaćeg proizvoda i osobne potrošnje ukoliko nema upravljanja rizikom. Stoga mnoge zemlje nemaju poticaj za specijalizacijom posebice zato što visoka volatilnost smanjuje štednju i investicije. Financijska globalizacija može pomoći zemljama u dijeljenju rizika i tako potaknuti gospodarski rast i smanjiti volatilnost potrošnje. Sljedeći indirektni kanal je povod za boljim politikama kojima se mijenja dinamika domaćih investicija i realocira kapital prema produktivnijim aktivnostima, i tako potiče gospodarski rast. Posljednji indirektni kanal je signaliziranje kojim se najavljuje da će zemlje u budućnosti provoditi politiku koja će poticati priljev stranog kapitala. Takvim potezom nagovještuje svoju spremnost da prihvati financijsku integraciju (Prasad, Rogoff, Wei, Kose, 2003.)<sup>3</sup>.

Do sada su se navodili samo potencijalni pozitivni rezultati financijske integracije na gospodarstva zemalja. Međutim, potencijalni troškovi financijske integracije, kao što su: koncentracija tokova kapitala, ulaganje kapitala u nekretnine, gubitak makroekonomske stabilnosti, financijske zaraze, porast makroekonomske volatilnosti (Agénor, 2003; Stiglitz, 2004.) mogu ublažiti ili u potpunosti ukloniti moguće pozitivne efekte financijske integracije. Teorija, međutim, još nije rasvijetlila dovodi li financijska integracija nužno do gospodarskog rasta. Stoga se moraju analizirati i empirijska istraživanja o kojima će više riječi biti u sljedećem dijelu.

<sup>3</sup> Primjer za to su zemlje poput Egipta, Italije, Novog Zelanda, Španjolske, Urugvaja i Ujedinjenog Kraljevstva koje su povećale kapitalni priljev nakon što su uklonili ograničenja na kapital.



#### 4. PREGLED EMPIRIJSKIH ISTRAŽIVANJA O UTJECAJU FINANCIJSKE INTEGRACIJE NA GOSPODARSKI RAST

U sklopu pregleda empirijskih istraživanja glavna će se pozornost posvetiti onim radovima koji se češće citiraju u empirijskoj literaturi za makroekonomske efekte financijske integracije i koji se usredotočuju na *de facto* mjere financijske integracije.

Među prvim od tih radova koji se u literaturi citiraju svakako je Kraayev (1998.) rad u kojem nije potvrđeno da financijska integracija utječe na gospodarski rast. Do jasnijih zaključaka nisu došli ni Bosworth i Collins (1999.), koji su analizirali utjecaj financijske integracije na investicije i štednju. Prema njima priljev FDI-ja pridonosi povećanju domaćih investicija, ali ne i portfolio tokovi i krediti. Nasuprot tome, međunarodni tokovi kapitala nemaju značajan učinak na štednju. Stoga se može zaključiti i da je utjecaj financijske integracije na gospodarski rast nejasan.

Edison, Levine, Ricci i Sløk (2002.) doprinose empirijskom istraživanju utjecaja financijske integracije na rast s dva nalaza. Prvi je da financijska integracija utječe pozitivno na rast samo unutar određenih institucionalnih i političkih faktora, kao što su: razvijeni bankovni sustav, razvijeno tržište dionica, dobro funkcionirajuće zakonodavstvo, niska razina korumpiranosti vlade, visoka razina bruto domaćeg proizvoda po glavi stanovnika, visok udio obrazovanih, fiskalna i monetarna ravnoteža, ali ta veza nije snažna. Drugi je nalaz potvrda (primjenom panel analize) da je financijska integracija pozitivno korelirana s bruto domaćim proizvodom po glavi stanovnika, razinom dohotka po stanovniku, razinom obrazovanja, te razvojem bankovnog sustava, tržišta dionica i institucija (niska razina vladine korupcije).

McLean i Shrestha (2002.) istražuju utječu li različiti tipovi kapitalnih priljeva različito na rast i pokazuju kako neto strane investicije i portfolio investicije imaju pozitivan i signifikantan utjecaj na gospodarski rast. Suprotno tome, utjecaj bankovnih kredita se pokazao negativnim.

Fratzcher i Bussiere (2004.) su potvrdili pozitivnu vezu između liberalizacije financijskih transakcija i gospodarskog rasta koja je, međutim, kratkoročnog karaktera. U srednjem i dugom roku zamijetili su čak negativnu vezu. Rezultati njihove analize pokazuju da su:

1. Zemlje s manjim početnim dohotkom po stanovniku kratkoročno imale veću korist od financijske liberalizacije;
2. Investicije u značajnijoj pozitivnoj korelaciji s gospodarskim rastom samo u godinama nakon liberalizacije, ali ne i u srednjem ili dugom roku;
3. Portfolio investicije u pozitivnoj vezi s gospodarskim rastom u kratkom, ali ne i u dugom roku. Suprotan zaključak vrijedi za priljev FDI-ja koji imaju pozitivan utjecaj na gospodarski rast u srednjem i dugom, ali ne i u kratkom roku;
4. Zemlje s kvalitetnijim domaćim institucijama su u dugom roku imale veću korist od financijske liberalizacije.

Bonfiglioli (2008.) potvrđuje da se utjecaj financijske globalizacije na gospodarski rast odražava kroz pozitivan učinak na produktivnost dok je učinak na akumulaciju kapitala nesignifikantan. Autorica je također potvrdila da financijska integracija sistemski ne povećava dubinu financijskog sektora, ali da može utjecati na pojavu bankovnih kriza.

Garita (2009.) analizira rastu li zemlje koje su financijski otvorenije brže od financijski zatvorenijih zemalja kako nalaže ekonomska teorija. Empirijska analiza do sada nije pronašla čvrst dokaz postojanja takve veze. Za zemlje u razvoju Garita potvrđuje pozitivni efekt priljeva FDI-ja (u neto izrazu) na rast bruto domaćeg proizvoda, ali i domaće investicije i akumulaciju kapitala. Portfolio investicije nemaju značajan efekt na akumulaciju kapitala. Rezultati istraživanja u razvijenim zemljama pokazuju kako FDI i portfolio investicija oboje pozitivno utječu na rast bruto domaćeg proizvoda po radniku, ali samo portfolio investicije imaju utjecaj na akumulaciju kapitala i domaće investicije. Ono što je zajedničko zemljama u razvoju i razvijenim zemljama je pozitivna i signifikantna korelacija između priljeva neto stranih investicija i TFP-a (ukupne faktorske produktivnosti).

Ne primjenjuju se u istraživanjima samo *de facto* mjere financijske otvorenosti kao indikatori financijske integracije. Neki od radova primjenjuju i druge indikatore. Primjerice, već spomenuti radovi (Kraay, 1998; Edison, Levine, Ricci, Sløk, 2002; Klein, Olivei, 2008.), pored *de facto* mjera, koriste „indikatore udjela“ koji označavaju udio godina u uzorku kad je kapitalni račun bio otvoren. Među onima koji koriste navedeni indikator neophodno je spomenuti i Rodrika (1998.), koji nije potvrdio da financijska otvorenost signifikantno utječe na rast. Levine (2001.) je za indikatora financijske integracije uzeo udio stranih banaka u ukupnom broju banaka i potvrdio da ono potiče efikasnost domaćeg bankovnog sektora i da liberalizacija međunarodnih portfolio tokova pridonosi likvidnosti tržišta dionica. Veća likvidnost tržišta dionica i razvijeniji bankovni sustav mogu poticati rast. Quinn (1997.) i Quinn (2003.) upotrebljavaju opisne deskripcije u AREAER-u za razvoj kvantitativne mjere financijske otvorenosti<sup>4</sup>. Navedene mjere su često primjenjivane u empirijskoj literaturi. Među njima je i Edwards (2001.), koji zaključuje da otvorenost kapitalnog računa pozitivno utječe na rast, ali tek nakon što je zemlja postigla određeni stupanj ekonomskog i financijskog razvoja, pa je, u protivnom, moguće očekivati negativne efekte financijske liberalizacije. Pored Quinnove mjere autor također koristi i mjere udjela. Quinnovu mjeru također primjenjuje i Bonfiglioli (2008.). Mjera financijske integracije kakvu koriste Hermes i Lensink (2008.) obuhvaća šest dimenzija politika na financijskom tržištu (kreditne kontrole, kontrole kamatnih stopa, prepreke za ulaz, operativne restrikcije za tržišta obveznica, privatizaciju financijskih institucija, restrikcije na međunarodne financijske transakcije) pri čemu vrijednost svake dimenzije ide od 0 – 3 (0 – potpuna financijska represija, 1 – parcijalna represija, 2 – jako liberalizirana, 3 – potpuno liberalizirana). Po autorima je to prikladniji indikator financijske globalizacije zato što se s jedne strane ne ograničava samo na jedan događaj što je slučaj kad se koriste binarne mjere; a s druge što se ne orijentira samo na jednu ili nekoliko dimenzija integracije poput Levineova (2001.) indikatora, koji se odnosi samo na otvorenost bankovnog sektora i tržišta dionica strancima. U svom radu istražuju povezanost financijske integracije sa štednjom i investicijama i konačno s rastom. Rezultati su pokazali da ne mora postojati pozitivan utjecaj financijske integracije na domaću štednju, već, naprotiv, on može biti negativan. Financijska integracija, prema njima, ima pozitivan efekt na privatne investicije i bruto domaći proizvod po glavi stanovnika. Negativna veza se pojavljuje kod utjecaja financijske integracije na javne investicije. Iz takvih rezultata se može zaključiti da financijska integriranost vodi supstituciji javnih privatnim investicijama, što može doprinijeti gospodarskom rastu.

<sup>4</sup> O ostalim autorima više vidi u Kose, i dr. (2006.).

Među radovima koji istražuju učinke financijske integracije neophodno je spomenuti rad Eichengreena (2001.), koji ističe da je empirijska analiza podbacila u davanju korisnih rezultata glede utjecaja financijske integracije na gospodarski rast, unatoč teorijskim stajalištima koji kazuju da međunarodna kretanja kapitala donose koristi i zaposlodavcima i zaposlojima. Od studija korelacije liberalizacije kapitalnog računa i rasta autor ističe spomenuti rad Rodrika (1998.) čiji su rezultati oprečni s Quinnovim (1997.), koji ističu pozitivnu, statistički značajnu i robusnu korelaciju između veće otvorenosti kapitalnog računa i rasta. Eichengreen razliku u ovim rezultatima objašnjava time što je u Quinnovu uzorku i „izgubljena dekada (1980-te)“ kada virtualno nisu postojala kapitalna kretanja koja bi stimulirala rast. Također navodi da Quinn ima više nezavisnih varijabli u modelu, te radije promatra promjene u otvorenosti kapitalnog računa nego razine. Kao bitnu razliku ta dva istraživanja navodi i činjenicu da se Quinnov uzorak odnosi na zemlje u razvoju, te stoga postoje razlozi da se vjeruje kako efekti liberalizacije kapitala variraju ovisno o financijskom i institucionalnom razvoju. McLean i Shrestha (2002.) posebno naglašavaju potrebu za oprežnošću kada se govori o izostanku statističke veze kao dokazu protiv financijske integracije. Mišljenja su da je ono moguće kao posljedica neadekvatnog mjerenja liberalizacije kapitalnog računa, te da takva mjera ne odražava u potpunosti kompleksni fenomen kao što je financijska integracija.

## **5. EMPIRIJSKO ISTRAŽIVANJE NA PRIMJERU POSTTRANZICIJSKIH ZEMALJA**

Predloženi empirijski radovi na zemljama koje nisu prošle proces tranzicije s planskog na tržišno gospodarstvo, nisu uspjeli u potpunosti potvrditi da financijska integracija pozitivno utječe na gospodarski rast. Premda to onda, u prvi mah, istraživanje takvog tipa u tranzicijskim zemljama čini besmislenim (uzimajući u obzir i znatno kraću vremensku komponentu, te broj i osobitosti posttranzicijskih zemalja), ipak valja još jednom istaknuti da je u ovim zemljama kapitalna oprema bila zastarjela. Zbog nedovoljne domaće štednje ulaganje u fizički i ljudski kapital zahtijevalo je pristup svjetskim financijskim tokovima. Stoga je predložena hipoteza prikladna, pa će se pristupiti njenom testiranju u ovom dijelu rada gdje je načinjen empirijski model kojim se analizira utjecaj financijske integracije na gospodarski rast posttranzicijskih zemalja. Empirijsko istraživanje započinje s izborom varijabli u model i s deskriptivnom statističkom analizom.

### **5.1. Izbor varijabli u model**

Podaci za sve varijable su na godišnjoj razini za razdoblje od 1990. do 2007. godine. Analiza će obuhvatiti 27 bivših socijalističkih zemalja (zemlje istočne i jugoistočne Europe, te ZND). Prije procjene samog modela dana je deskriptivna statistička analiza varijabli koje su uključene u model čiji se rezultati nalaze u tablici 1. U modelu su primjenjivane varijable, kao što su: neto kamatna marža (varijabla NIM), udio potrošnje opće države na finalna dobra i usluge u GDP-u (varijabla GOVERNMENT), udio vanjske trgovine (zbroj uvoza i izvoza) u GDP-u (varijabla TRADE), zbroj ukupne aktive i pasive u Međunarodnoj investicijskoj poziciji zemlje podijeljen s GDP-em (varijabla IFIGDP) ili vanjskom trгови-



nom (varijable IFITRADE), zbroj direktnih i portfolio vlasničkih investicija u inozemstvo s direktnim i portfolio vlasničkim investicijama iz inozemstva podijeljen s GDP-em (varijabla GEQGDP) ili vanjskom trgovinom (varijabla GEQTRADE), udio direktnih i portfolio vlasničkih investicija u ukupnim investicijama iz inozemstva (varijabla EQSHARE), te GDP. Stopa rasta GDP-a (DLOGGDP) je definirana kao razlika logaritama GDP-a iz perioda  $t$  i  $t-1$ .

Podaci za varijable GOVERNMENT, TRADE, GDP su preuzeti iz WDI-a (*World Development Indicators*) (World Bank, 2009.). Varijable IFIGDP, IFITRADE, GEQGDP, GEQTRADE i EQSHARE su indikatori financijske integracije čije su vrijednosti preuzete iz Lane, Milesi-Ferretti (2007.) i Lane, Milesi-Ferretti (2009.). Vrijednost NIM je preuzeta iz Beck, Demirgüç-Kunt, Levine (2009.).

## 5.2. Deskriptivna statistička analiza

Analiza je započeta primjenom deskriptivne statistike čiji su rezultati za sve varijable predstavljeni u tablici 1.

**Tablica 1.** Deskriptivna statistička analiza varijabli uključenih u model

Varijabla	Sredina	Standardna devijacija	Minimum	Maksimum	Opažanja
NIM	0.066866	0.045543	0.014392	0.3295971	N = 320
GOVERNMENT	0.171638	0.049138	0.056903	0.301244	N = 460
TRADE	0.971959	0.333033	0.222287	1.996796	N = 467
IFIGDP	1.123409	0.640403	0.167378	8.157424	N = 392
GEQGDP	0.284887	0.2838	0.001728	2.556561	N = 398
IFITRADE	1.207885	0.707829	0.162251	9.865975	N = 392
GEQTRADE	0.284931	0.252047	0	1.729401	N = 400
EQSHARE	0.32487	0.192755	0	0.86389	N = 392
GDP	3.17E+10	6.28E+10	7.16E+08	4.06E+11	N = 475
DLOGGDP	0.01362	0.106657	-0.59602	0.636353	N = 448
INFLACIJACPI	99.48311	422.2732	-8.52517	4734.915	N = 357

Varijabla NIM se odnosi na neto kamatnu maržu i iskazana je kao postotak. Prosječna vrijednost kamatne marže u promatranom vremenskom razdoblju je iznosila 6.68% s prosječnim odstupanjem od prosjeka 4.46%.

GOVERNMENT iskazuje udio potrošnje opće države na finalna dobra i usluge u GDP-u, te je također postotak. Podaci za ovu varijablu pokazuju da u prosjeku u promatranom razdoblju iznosi 17% s prosječnim odstupanjem od prosjeka 4.9%.

Varijablom TRADE se mjeri udio vanjske trgovine (kao zbroj uvoza i izvoza u GDP-u), pa je također iskazana kao postotak. On se u promatranom razdoblju kretao u prosjeku od 97% s prosječnim odstupanjem od prosjeka 33%.

Varijabla IFIGDP predstavlja udio ukupnih financijskih tokova (direktnih i portfolio) u GDP-u, te je također iskazana kao postotak. Ukupni financijski tokovi u prosjeku zauzimaju 112% GDP-a, s tim da je prosječno odstupanje od prosjeka 64%.

Varijabla IFITRADE predstavlja udio ukupnih financijskih tokova u ukupnoj vanjskoj trgovini, pa je također iskazana kao postotak. Ukupni financijski tokovi u prosjeku zauzimaju 129.79% ukupne trgovine s prosječnim odstupanjem od prosjeka 70.78%.

Udio ukupnih vlasničkih financijskih tokova (i direktnih i portfolio vlasničkih) u GDP-u je predstavljen varijablom GEQGDP koja je s toga iskazana kao postotak. Ukupni vlasnički financijski tokovi u prosjeku zauzimaju 28% s istovjetnim prosječnim odstupanjem od prosjeka.

Udio ukupnih vlasničkih financijskih tokova (i direktnih i portfolio vlasničkih) u ukupnoj trgovini je predstavljen varijablom GEQTRADE, pa je također iskazana kao postotak. Ukupni vlasnički financijski tokovi u prosjeku zauzimaju 28%, ali je prosječno odstupanje od prosjeka 25%.

Varijabla EQ\_SHARE predstavlja udio vlasničkih ulaganja iz inozemstva u ukupnim ulaganjima iz inozemstva, te je također postotak. U prosjeku iznosi oko 32%, s prosječnim odstupanjem od prosjeka 19%.

Stopa rasta GDP-a (DLOGGDP) je iskazana kao razlika logaritama GDP-a između godine  $t$  i  $t-1$ . Prosječna vrijednost stope rasta GDP-a iznosi 1.34% s prosječnim odstupanjem od 10.66%.

Inflacija mjerena kao postotna promjena indeksa potrošačkih cijena (varijabla INFLACIJACPI<sup>5</sup>) u prosjeku iznosi 99.48% s prosječnim odstupanjem od 422%.

### 5.3. Model i očekivani rezultati

Model koji se ovdje testira sličan je onom koji su već postavili za netranzijske zemlje Edison, Levine, Ricci i Sløk (2002.). U općenitom obliku on glasi:

$$GROWTH_{it} = \alpha_i + \beta IFI_{it} + \gamma X_{it} + \varepsilon_{it} . \quad (1)$$

Terminom  $IFI_{it}$  obuhvaćen je indikator financijske integracije neovisno o tome o kojem je indikatoru riječ.  $X_{it}$  predstavlja vektor kontrolnih varijabli. U kontrolne varijable ubrajaju se inflacija mjerena kao postotna promjena CPI-ja (INFLACIJACPI), GOVERNMENT, TRADE i GDP. Zavisna varijabla u modelu ( $GROWTH_{it}$ ) je DLOGGDP.

Prema samoj definiciji stope rasta dohotka (DLOGGDP) na ovu varijablu u  $t$  utjecaja imaju razine dohotka u  $t$  i  $t-1$ . Za danu razinu dohotka u  $t$  veća će biti stopa rasta dohotka što je razina dohotka u prethodnom vremenu bila manja, pa se, dakle, može očekivati negativna korelacija između varijabli  $GDP_{t-1}$  i DLOGGDP<sub>t</sub>.

Ukoliko je stopa inflacije (INFLACIJACPI) niska može se očekivati pozitivna veza između rasta CPI-ja i DLOGGDP. Međutim, ukoliko je stopa inflacije jako visoka tada je to pokazatelj nestabilnosti u cjelokupnoj ekonomiji. U takvim situacijama realno je očekivati

<sup>5</sup> Varijabla INFLACIJACPI je već u podacima pomnožena sa 100.

negativan učinak inflacije na gospodarski rast, pa je očekivan utjecaj inflacije na gospodarski rast nepoznat.

Za parametar uz varijablu GOVERNMENT očekuje se negativan predznak jer je iz ekonomske literature poznato da veći udio vladine potrošnje u GDP-u dovodi do istiskivanja privatnih investicija (IS-LM model), što onda pridonosi i manjem gospodarskom rastu.

U većini literature potvrđeno je da varijabla TRADE ima pozitivan učinak na gospodarski rast, ali niz istraživanja također potvrđuje da veća otvorenost privrede znači i veći rast u ekonomijama s boljom kvalitetom javne uprave, pa se čini da je veći rast zajamčen za zemlje koje potiču priljev inozemnog kapitala (Levine, 2001; Edison, Levine, Ricci, Sløk, 2002; Bonfiglioli, 2005; Bonfiglioli, 2007.). Druga istraživanja poput Krugmanova (prema Levine, 2001.), i Rodrikova (1998.) naglašavaju negativnu vezu otvorenosti i rasta dohotka, odnosno pozitivna veza otvorenosti i gospodarskog rasta može vrijediti samo za zemlje koje imaju veliki dohodak (Rodrik, 1998.). Stoga je očekivani predznak parametra uz varijablu TRADE nepoznat.

Očekivani predznaci parametara regresijskih jednadžbi nalaze se u tablici 2.

**Tablica 2.** Očekivani predznaci parametara regresijskih jednadžbi

Varijabla	Opis	Očekivani predznak
$GDP_{t-1}$	Razina dohotka iz prethodnog razdoblja ( $t-1$ )	Negativan
GOVERNMENT	Udio potrošnje opće države na finalna dobra i usluge u GDP-u	Negativan
TRADE	Udio trgovine u GDP-u	Nepoznat
INFLACIJACPI	Postotna promjena indeksa potrošačkih cijena	Nepoznat
NIM	Neto kamatna marža	Negativan
Financijska integracija (svi indikatori)	Stupanj financijske integracije	Pozitivan

NAPOMENA: Sve su varijable definirane kao logaritmi osim inflacije.

## 5.4. Model s fiksnim efektima

### 5.4.1. Model bez vremenskih efekata

Pošto je izvršena deskriptivna statistička analiza, te predložen konkretan model s očekivanim rezultatima analize, u nastavku rada primjenjivat će se panel analiza. Budući da je vremenska serija u panelu za pojedine zemlje različita, panel model je neuravnotežen.

Panel model se može prikazati kao (2) <sup>6</sup>:

$$y_{it} = \beta_{1i} + \sum_{k=2}^K \beta_k x_{kit} + u_{it} \quad (2)$$

<sup>6</sup> Jednostavan prikaz panel analize vidi u Wooldridge (2003.).

pri čemu je  $i$  indeks za individualnu, a  $t$  vremensku komponentu u panelu. Već  $\beta_{it}$  upućuje na razliku u slobodnim članovima među individualnim jedinicama – pojedinačnu heterogenost (*individual heterogeneity*) koja se odnosi na efekte koji variraju od zemlje do zemlje, a da se ne mijenjaju kroz vrijeme<sup>7</sup>. Takav model predstavlja panel model s fiksnim efektima koji se procjenjuje metodom najmanjih kvadrata (OLS). Ograničeni oblik ovog modela uključuje mogućnost da su slobodni članovi jednaki odnosno da u (2) vrijedi  $\beta_{it} = \beta_i$ . Takav model se sada naziva združena regresija (*pooled regression*).

Transformacijom modela (2) dobiva se sljedeći model:

$$y_{it} = \beta_0 + \sum_{k=2}^K \beta_k x_{kit} + \varepsilon_{it} \quad (3)$$

gdje je  $\varepsilon_{it} = (\beta_{1i} - \beta_0) + u_{it}$ . Ovako postavljeni model je model sa slučajnim efektima. Kako sada postoji autokorelacija grešaka unutar individualnih jedinica, testiranje metodom najmanjih kvadrata nije prikladno, te se primjenjuje opća metoda najmanjih kvadrata.

Bitna razlika između modela s fiksnim efektima i modela sa slučajnim efektima jest u mogućnosti korelacije između kontrolnih varijabli i pojedinačnih nejednakosti. Ekonomskim primjerom rečeno, neke zemlje mogu privući više kapitala upravo zbog toga što imaju manji stupanj korupcije, kvalitetniju birokraciju i veći stupanj vladavine prava, premda se ovi indikatori ne mijenjaju tijekom vremena. U tim uvjetima prihvatljiviji je model s fiksnim efektima jer dozvoljava korelaciju između ovih „fiksni“ faktora i kontrolnih varijabli. Kada takve korelacije nema, prihvatljiviji je model sa slučajnim efektima. Za donošenje odluke o ispravnosti modela s fiksnim ili slučajnim efektima primjenjuje se Hausmanov test specifikacije (Maddala, 2001.). Nedostatak je ovog testa što vrijednosti Hausmanove statistike mogu poprimiti negativne vrijednosti, pa neki autori preporučuju korištenje njene apsolutne vrijednosti (Schreiber, 2008.)<sup>8</sup>. Ukoliko je prihvaćen model s fiksnim efektima, proveden je i Chowov test kako bi se utvrdilo je li možda združena regresija prikladnija naspram modela s fiksnim efektima. Nasuprot tome, ukoliko je Hausmanov test prihvatio model sa slučajnim efektima, tada se prihvatljivost združene regresije u odnosu na ovaj model testira Breusch-Paganovim LM testom (Baltagi, 2005.).

Budući da su podaci na godišnjoj razini testirana je autokorelacija prvog reda u slučaju modela s fiksnim ili sa slučajnim učincima, primjenom Wooldridgeova (2002.) testa. Za testiranje heteroskedastičnosti primijenjen je modificirani Waldov test (Greene, 2000.). U svim slučajevima je potvrđena i autokorelacija prvog reda i heteroskedastičnost, pa se prišlo korekciji standardnih pogreški<sup>9</sup>.

<sup>7</sup> Takvi efekti mogu biti stupanj korupcije, kvaliteta birokracije, pravna sigurnost, a zajedničko im je da se ne mijenjaju (ili se jako sporo mijenjaju) tijekom vremena unutar neke zemlje, ali se mogu značajno razlikovati unutar skupine zemalja. U takvim uvjetima zemlje mogu privući više investicija upravo zbog toga što imaju manji stupanj korupcije, kvalitetniju birokraciju i veći stupanj vladavine prava, premda se ovi indikatori ne mijenjaju tijekom vremena.

<sup>8</sup> Valja također imati u vidu da i ako su korelacije pojedinačnih nejednakosti i regresijskih vrijednosti visoke tada valja prihvatiti model s fiksnim efektima jer se kod slučajnih pretpostavlja da su one jednake nuli. U svim regresijama koje slijede su ove korelacije bile jako visoke.

<sup>9</sup> Procjenitelji dobiveni metodom najmanjih kvadrata su nepristrani i konzistentni u uvjetima autokorelacije i heteroskedastičnosti, ali više nisu efikasni jer su im varijance veće nego u slučaju odsutnosti ovih dviju pojava. To otežava primjenu t-testova u donošenju odluka o signifikantnosti pojedinih varijabli, te bi



Tablica 3. Ispis rezultata modela s fiksnim efektima

Model s fiksnim efektima i klasteriranim pogreškama					
Zavisna varijabla: DLOGGDP					
Kontrolna varijabla	IFIGDP	GEQGDP	IFITRADE	GEQTRADE	EQSHARE
NIM	-0.04021 (0.01005)**	-0.04117 (0.01069)**	-0.04021 (0.01005)**	-0.04117 (0.01069)**	-0.04032 (0.01124)**
INFLACIJACPI	-0.0002 (0.00005)**	-0.0002 (0.00006)**	-0.0002 (0.00005)**	-0.0002 (0.00006)**	-0.0002 (0.00006)**
GOVERNMENT	-0.0364 (0.02233)	-0.03651 (0.01969)+	-0.0364 (0.02233)	-0.03651 (0.01969)+	-0.03596 (0.01884)+
TRADE	0.05006 (0.02402)*	0.0539 (0.02572)*	0.04986 (0.02749)+	0.05207 (0.02273)*	0.05131 (0.02300)*
IFIGDP	-0.00021 (0.01776)				
GDP_1	0.01831 (0.03538)	0.01971 (0.03531)	0.01831 (0.03538)	0.01971 (0.03531)	0.01865 (0.03299)
GEQGDP		-0.00184 (0.01055)			
IFITRADE			-0.00021 (0.01776)		
GEQTRADE				-0.00184 (0.01055)	
GEQSHARE					-0.00095 (0.0121)
Konstanta	-0.5572 (0.83574)	-0.59533 (0.83224)	-0.5572 (0.83574)	-0.59533 (0.83224)	-0.56577 (0.76085)
Opažanja	287	287	287	287	287
Broj grupa	23	23	23	23	23
R <sup>2</sup>	0.49	0.49	0.49	0.49	0.49
Robustne (i klasterirane) standardne pogreške u zagradama					
+ signifikantno pri 10%; * signifikantno pri 5%; ** signifikantno pri 1%					

valjalo standardne pogreške korigirati. Ako se tako uklanjaju samo posljedice heteroskedastičnosti takav procjenitelj standardne pogreške biva polu-robustan (*semi-robust*), a ako i heteroskedastičnosti i autokorelacije, tada je robustan (*robust*).

Rezultati koji su prezentirani u tablici 3, upućuju na zaključak da na gospodarski rast signifikantno utječu kamatna marža i udio vanjske trgovine u GDP-u s očekivanim predznacima. Od preostalih varijabli se signifikantnom pokazala još samo INFLACIJACPI, ali je veličina koeficijenta uz navedenu varijablu zanemarivo mala.

#### 5.4.2. Model s dvostrukim fiksnim efektima

Osim što se mogu promatrati individualni efekti koji se ne mijenjaju kroz vrijeme, ali su promjenjivi s obzirom na individualne jedinice, moguće je također promatrati i efekte koji su promjenjivi kroz vrijeme, ali ne i kroz individualne jedinice. Takav model je moguće postaviti s jednadžbom:

$$y_{it} = \beta_1 + \sum_{k=2}^K \beta_k x_{kit} + \mu_i + \lambda_t + u_{it}. \quad (4)$$

Pri tome su u (4)  $\lambda_t$  efekti vremenskih varijabli koji nisu eksplicitno uključeni u model na varijacije zavisne varijable tijekom vremena.  $\mu_i$  označava individualne efekte. Prosjek od  $y_{it}$  s obzirom na vrijeme dan je izrazom:

$$\bar{y}_t = \sum_{i=1}^N \frac{y_{it}}{N} = \beta_1 + \sum_{k=2}^K \beta_k \bar{x}_{kt} + \mu_i + \bar{\lambda}_t + \bar{u}_t. \quad (5)$$

Prosjek od  $y_{it}$  s obzirom na individualnu komponentu dan je izrazom:

$$\bar{y}_i = \sum_{t=1}^T \frac{y_{it}}{t} = \beta_1 + \sum_{k=2}^K \beta_k \bar{x}_{ki} + \bar{\mu}_i + \lambda_t + \bar{u}_i. \quad (6)$$

Ukupan prosjek od  $y_{it}$  bit će dan kao:

$$\bar{y} = \beta_1 + \sum_{k=2}^K \beta_k \bar{x}_K + \mu_i + \lambda_t + \bar{u}. \quad (7)$$

Oduzimanjem (5) i (6) od (4) te dodavanjem (7) dobiva se sljedeći oblik modela:

$$(y_{kit} - \bar{y}_{ki} - \bar{y}_{kt} + \bar{y}) = \sum_{k=2}^K \beta_k (x_{kit} - \bar{x}_{ki} - \bar{x}_{kt} + \bar{x}) + (u_{it} - \bar{u}_i - \bar{u}_t + \bar{u}). \quad (8)$$

Kovarijančnim modelom (8) su otklonjeni individualni i vremenski efekti.

Ukoliko je vremenska dimenzija u panel modelu mala tada se model s dvostrukim fiksnim efektima, kako se često naziva model s fiksnim individualnim i vremenskim efektima, može procijeniti primjenom jednostrukog modela s fiksnim efektima:

$$y_{it} = \beta_1 + \sum_{k=2}^K \beta_k x_{kit} + \sum_{s=1}^{T-1} \lambda_s D_{st} + \mu_i + u_{it} \quad (9)$$

pri čemu su sa  $D_s$  dane *dummy* varijable za godinu  $s$ .  $\lambda$  se definira kao razlika od godine  $T$ , a ne kao odstupanje od prosjeka.

Procjene parametara modela s dvostrukim fiksnim efektima dane su u Dodatku 1, da se ne opterećuje tekst. Sada su vrijednosti koeficijenta uz varijablu NIM nešto manje, ali je to, uz INFLACIJACPI i dalje jedina varijabla koja je signifikantna u modelu u svim slučajevima<sup>10</sup>. Međutim koeficijent uz INFLACIJACPI je zanemarivo mali. Signifikantnom se u dva od pet slučajeva pokazala i varijabla GOVERNMENT, što ne vrijedi i za ostale varijable u modelu. Razlika je u trenutno analiziranom modelu i što varijabla TRADE više nije signifikantna kao što je to bilo u prethodno postavljenom modelu.

### 5.4.3. Dinamički panel model

Sva dosadašnja testiranja u ovom radu zanemarila su mogućnost da zavisna varijabla u samom modelu bude AR(1) ili proces slučajnog pomaka. U oba slučaja zavisna varijabla ovisi o svojoj vrijednosti iz proteklog razdoblja. Vrijednost zavisne varijable s vremenskim pomakom<sup>11</sup> bit će u korelaciji s individualnim efektom i primjena OLS metode u takvoj situaciji dovest će do pristranih i nekonzistentnih procjenitelja.

Kao moguće rješenje navedenog problema navodi se uvođenje *dinamičkog panela*<sup>12</sup>. Kao primjer jednog takvog modela može se istaknuti i sljedeći model:

$$Y_{it} = \gamma Y_{it-1} + \beta X_{it} + \alpha_i + \varepsilon_{it} \quad (10)$$

pri čemu je  $\alpha_i$  fiksni efekt ili pojedinačna heterogenost,  $X_{it} \in R^{k-1}$  vektor egzogenih regresora i  $\varepsilon_{it} \sim N(0, \sigma_\varepsilon^2)$  slučajno odstupanje. Pretpostavlja se da je varijanca odstupanja nenegativna, da ne postoji serijska korelacija među odstupanjima, da nema korelacije slučajnih odstupanja i fiksnih efekata i korelacije između regresora i slučajnih varijabli. U makroekonomskoj analizi najčešće se koriste modeli s fiksnim efektima i to iz dva razloga (Judson, Owen, 1996.):

1. Ako individualni slučajevi prikazuju izbačene varijable, vjerojatnije je da su specifične karakteristike zemalja korelirane s drugim regresorima;
2. Vjerojatnije je da makroekonomski uzorak sadržava većinu interesantnih zemalja, pa je malo vjerojatno da će biti slučajan uzorak iz velikog skupa zemalja.

Model (10) se može procjenjivati s metodom najmanjih kvadrata (OLS) kao model s fiksnim efektima (2), ali može i s uvođenjem *dummy* varijabli (LSDV procjenitelj – *least square dummy variable estimator*). Procjenjivanje modela (10) LSDV-om bi, kao što je pokazao Nickell (1981.), urodilo velikom pristranošću za  $\gamma$  koja bi težila 0 kako se vremenska dimenzija panela povećava. Tako bi on bio prikladan za „duboke“ panele, što nije slučaj kada se analiziraju tranzicijske zemlje. Pri analizi tranzicijskih zemalja puno bi korisniji bio panel s plitkom serijom.

<sup>10</sup> Svi su testovi rađeni pri razini signifikantnosti od 5% ukoliko nije navedeno drukčije.

<sup>11</sup> U ostatku teksta za varijablu s vremenskim pomakom će se upotrebljavati termin lagirana vrijednost, a za vremenski pomak lag.

<sup>12</sup> Niz radova o dinamičkom panelu moguće je naći u Baltagi (2000.).

Prvi procjenitelj koji je prikladan za plitke panele je Anderson-Hsiaoov (AH) procjenitelj koji su predložili Anderson i Hsiao (1981.). Navedeni autori su predložili da se diferencira jednačba (10) čime se otklanja fiksni efekt:

$$(Y_{it} - Y_{it-1}) = \gamma(Y_{it-1} - Y_{it-2}) + \beta(X_{it} - X_{it-1}) + (\varepsilon_{it} - \varepsilon_{it-1}). \quad (11)$$

Međutim, ovdje je jedan problem zamijenjen drugim jer su greške relacije  $(\varepsilon_{it} - \varepsilon_{it-1})$  korelirane s nezavisnom varijablom  $(Y_{it-1} - Y_{it-2})$  što traži pronalaženje instrumenta za  $(Y_{it-1} - Y_{it-2})$ . Kao instrument se može upotrijebiti lagirane razine  $Y_{it-2}$  ili lagirane diferencije  $(Y_{it-2} - Y_{it-3})$  koji nisu korelirani s greškom u (11), ali su korelirani s  $(Y_{it-1} - Y_{it-2})$  (Judson, Owen, 1996., str. 4.). Uzme li se lagirana razina kao instrument tada je AH procjenitelj dan s (Judson, Owen, 1996.)<sup>13</sup>:

$$\hat{\delta}_{AH} = (Z'X)^{-1}(Z'Y) \quad (12)$$

pri čemu je  $Z$  matrica instrumenata, a  $X$  matrica regresora, obje formata  $K \times N(T-2)$ , a  $Y$  vektor reda  $N(T-2)$  pa vrijedi:

$$Z_i = \begin{bmatrix} y_{i1} & \Delta x_{i,3} \\ \cdot & \cdot \\ \cdot & \cdot \\ y_{iT-2} & \Delta x_{i,T} \end{bmatrix} \quad X_i = \begin{bmatrix} \Delta y_{i2} & \Delta x_{i,3} \\ \cdot & \cdot \\ \cdot & \cdot \\ \Delta y_{iT-1} & \Delta x_{i,T} \end{bmatrix} \quad Y_i = \begin{bmatrix} \Delta y_{i,3} \\ \cdot \\ \cdot \\ \Delta y_{i,T} \end{bmatrix} \quad (13)$$

$$Z = \begin{bmatrix} Z_1 \\ \cdot \\ \cdot \\ Z_N \end{bmatrix} \quad X = \begin{bmatrix} X_1 \\ \cdot \\ \cdot \\ X_N \end{bmatrix} \quad Y = \begin{bmatrix} Y_1 \\ \cdot \\ \cdot \\ Y_N \end{bmatrix}. \quad (14)$$

Arellano-Bondov (1991.) jednofazni procjenitelj (AB) za dinamički panel model zasnovan je na primjeni generalizirane metode momenata (GMM). Pri procjeni se kao instrumenti koriste lagirane vrijednosti zavisne varijable, te lagirane vrijednosti egzogenih regresora. Takav jednofazni procjenitelj bit će dan izrazom:

$$A_N = \left( \frac{1}{N} \sum_{i=1}^N Z_i^* H Z_i \right)^{-1} \quad (15)$$

pri čemu je  $Z^*$  blok dijagonalna matrica čiji je  $s$ -ti blok dan kao  $(y_{it} \dots y_{is} x_{i1} \dots x_{i(s+1)})$  za  $s = 1, \dots, T-2$ , pa je  $Z^* = (Z_1^*, \dots, Z_N^*)'$ .  $H$  matrica je jedinstveno definirana kao:

<sup>13</sup> Anderson i Hsiao (1983.) su predložili dva procjenitelja bazirana na instrumentalnim varijablama pri čemu za instrumente sugeriraju druge lagove zavisne varijable, bilo u diferencijama, bilo u razinama.



$$H = \begin{bmatrix} 2 & -1 & 0 & . & . & . & 0 & 0 \\ -1 & 2 & -1 & . & . & . & 0 & 0 \\ . & . & . & . & . & . & . & . \\ . & . & . & . & . & . & . & . \\ . & . & . & . & . & . & . & . \\ 0 & 0 & 0 & . & . & . & 2 & -1 \\ 0 & 0 & 0 & . & . & . & -1 & 2 \end{bmatrix} \quad (16)$$

dakle kao matrica reda  $T-2$  s dvojkama na glavnoj dijagonali, -1 na prvim poddijagonalama i 0 na drugim mjestima. Dvofazni AB procjenitelj uključuje još i rezidualne iz regresije koja je ocijenjena jednofaznim procjeniteljem, te je dan izrazom:

$$A_N = \left( \frac{1}{N} \sum_{i=1}^N Z_i^{*'} \Delta \varepsilon_i \Delta \varepsilon_i' Z_i^* \right)^{-1} \quad (17)$$

pri čemu su reziduali označeni s:  $\Delta \varepsilon = \begin{pmatrix} \Delta \varepsilon_{i3} \dots \Delta \varepsilon_{iT} \end{pmatrix}$ .

Kiviet (1995.) je izveo formulu za pristranost LSDV procjenitelja i oduzeo ju od samog procjenitelja. Tako dobiveni procjenitelj nosi naziv korigirani LSDV procjenitelj (LCDVC).

Judson i Owen (1996.) su primjenom Monte Carlo simulacije istražili prikladnost svakog od navedenih procjenitelja za dinamički panel. Rezultati njihove analize mogu se svesti na sljedeće:

1. Pristranost za  $\gamma$  se pokazala ozbiljnijom nego za  $\beta$  i kod OLS i kod LSDV procjenitelja, pri čemu se ona za OLS još i povećava što je panel „dublji“. Pristranost za LSDV raste s većim  $\gamma$  i smanjuje se s većim  $T$  kako je ustanovio i Nickell (1981.);
2. Jednofazni Arellano-Bondov procjenitelj ostvaruje manju pristranost i veću efikasnost u odnosu na dvofazni procjenitelj. Anderson-Hsiaoov procjenitelj se razlikuje od Arellano-Bondova procjenitelja po tome što sadrži samo jedan lag zavisne varijable;
3. U ukupnoj ocjeni svi su procjenitelji (osim OLS) bolji ako se  $N$  poveća, odnosno što je veća širina panela – pri tome se prosječna pristranost kako raste  $N$  najviše smanjuje kod GMM procjenitelja, nasuprot LSDV-u. Unatoč tome procjenitelji dobiveni GMM-om ipak nisu superiorni u terminima prosječne pristranosti ili efikasnosti i relativne performanse ovih procjenitelja se ne mijenjaju općenito kako se  $N$  povećava. Praktički svi procjenitelji (osim OLS) su bolji kako se povećavaju  $N$  i  $T$ . Međutim, AH procjenitelj ima najnižu prosječnu pristranost, ali je LSDVC efikasniji;
4. Ako panel ima malu vremensku dimenziju ( $T < 10$ ) preporučuje se korištenje LSDVC procjenitelja, ali ako je panel dublji onda korištenje AH procjenitelja.

LSDVC procjenitelj čini se prihvatljivim u plitkim panelima kakvi se primjenjuju u tranzicijskim zemljama. Međutim, i taj procjenitelj ima nedostatke (Judson, Owen, 1996., str. 15. - 16.):

1. LSDVC tehnika ne može se primijeniti na neuravnoteženi panel;
2. Ne postoji analitička forma za standardne pogreške, pa je nužno primijeniti *bootstrap* tehniku da bi se procijenile standardne greške.

Blundell i Bond (1998. prema Bruno, 2005.a) su pokazali da i procjenitelji na temelju instrumentalnih varijabli ili na temelju generalizirane metode momenata mogu patiti od ozbiljne pristranosti zbog malog uzorka, ako su instrumenti loši. Model koji su oni razmatrali je mali autoregresivni panel model oblika (Baltagi, 2000.):

$$y_{it} = \delta y_{it-1} + \mu_i + v_{it} \quad (18)$$

pri čemu je  $E(\mu_i) = 0$ ;  $E(v_{it}) = 0$  i  $E(\mu_i v_{it}) = 0$  za  $i = 1, 2, \dots, N$ ;  $t = 1, 2, \dots, T$ . Oni predlažu sistemskog GMM procjenitelja s instrumentima koji su diferencirani ako su jednadžbe u razinama, i instrumenti u razinama, ako su jednadžbe dane kao prve diferencije. Galliani i González-Rozada (2002.) su pokazali da je navedeni procjenitelj bolji nego Arellano-Bondov.

Nedostatak Kivietove korekcije modela LSDV jest upravo što se navedeni procjenitelj ne može primijeniti ukoliko je panel neuravnotežen. Kvaliteta i dostupnost podataka u tranzicijskim zemljama bitno pridonosi neuravnoteženom panelu. Na taj način i sam navedeni procjenitelj za tranzicijske zemlje možda ne bude od koristi. Međutim, u Bruno (2005.b) je procijenjena pristranost LSDV procjenitelja za neuravnotežene dinamičke panele. Kako su svojstva i procjenitelja s instrumentalnim varijablama i s generaliziranom metodom momenata zadovoljena kada je  $N$  velik, mogu biti ozbiljno pristrani i neprecizni u panel podacima s malim brojem pojedinaca, pa je u Bruno (2005.a) korigirana pristranost zbog malog broja pojedinaca. To omogućuje primjenu LSDVC procjenitelja i u tranzicijskim zemljama s neuravnoteženim panelom, ali malim brojem pojedinaca. Uvjet za prikladnost LSDVC jest prisutnost striktno egzogenih regresora.

### *Rezultati empirijske analize uz primjenu dinamičkog panel modela*

Prije primjene dinamičke panel analize valja ustanoviti ovisi li vrijednost varijable DLOGGDP u  $t$  o vrijednosti iste u prethodnom razdoblju. Početni korak u toj analizi bit će izrada korelograma za ovu varijablu, koji je predložen slikom 1:

**Slika 1.** Korelogram varijable DLOGGDP

Sample: 1990 2007

Included observations: 448

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
. *****	. *****	1	0.621	0.621	174.00	0.000
. **	* .	2	0.334	-0.084	224.57	0.000
. *	. .	3	0.143	-0.049	233.86	0.000
. .	. .	4	0.044	-0.007	234.74	0.000
. .	. .	5	-0.008	-0.018	234.77	0.000
. .	. .	6	0.004	0.046	234.78	0.000
. .	. .	7	-0.020	-0.057	234.96	0.000
. .	. .	8	-0.065	-0.062	236.91	0.000
* .	. .	9	-0.101	-0.039	241.55	0.000
* .	. .	10	-0.122	-0.040	248.35	0.000
* .	. .	11	-0.143	-0.057	257.77	0.000
* .	* .	12	-0.164	-0.069	270.17	0.000

Grafikon parcijalne autokorelacije upućuje na mogućnost da se radi o AR(1) procesu, ali taj zaključak ne potvrđuju p-vrijednosti Ljung-Boxove Q – statistike. Pri svim lagovima  $k$  one odbacuju nultu hipotezu da ne postoji autokorelacija do reda  $k$ . Međutim, kod ove statistike javlja se problem izbora vremenskog pomaka jer, ako je pomak mali, neće se otkriti autokorelacija višeg reda, a ako je veliki test može imati malu snagu. Stoga je potrebno provesti dodatne testove. Konkretno radi se o primjeni testova jediničnog korijena na panel podacima. U odnosu na testove jediničnog korijena u običnim vremenskim serijama, oni u panel analizi imaju znatno veću snagu. Njihovi se rezultati nalaze u tablici 4. U svim slučajevima pri razini signifikantnosti od 5% ovim testovima je odbijena nulta hipoteza o postojanju zajedničkog ili pojedinačnih jediničnih korijena. Može se prema tome pretpostaviti da zavisna varijabla u našem modelu slijedi AR(1) proces.

**Tablica 4.** Rezultati testova jediničnog korijena na panel podacima

Panel unit root test: Summary

Series: DLOGGDP

Sample: 1990 2007

Exogenous variables: Individual effects

Automatic selection of maximum lags

Automatic lag length selection based on SIC: 0 to 3

Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross-sections	Obs
Null: Unit root (assumes common unit root process)				
Levin, Lin & Chu $t^*$	-10.5166	0.0000	27	407
Null: Unit root (assumes individual unit root process)				
Im, Pesaran and Shin W-stat	-6.53600	0.0000	27	407
ADF - Fisher Chi-square	150.271	0.0000	27	407
PP - Fisher Chi-square	427.763	0.0000	27	421

\*\* Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

Dobiveni rezultati opravdavaju primjenu dinamičkog modela. S obzirom na to da je u modelima s kratkom vremenskom serijom prema Judson i Owen (1996.) najprihvatljivija primjena Anderson-Hsiaoovog (1981.) i korigiranog LSDV procjenitelja, oni će se primjenjivati u daljnjoj analizi. Kada je broj pojedinaca relativno malen AH procjenitelj je pristran, te je Bruno (2005.a) izveo formulu za korekciju pristranosti u početnom procjenitelju koji može biti Arellano-Bondov, Blunell-Bondov ili Anderson-Hsiaoov. Premda je broj pojedinaca  $N = 27$  može se pretpostaviti korektnost primjene korigiranog LSDV procjenitelja. S obzirom na to da je vremenski efekt već potvrđen u modelu s fiksnim efektima on će biti zadržan i u dinamičkom modelu. U radu neće biti dostupni rezultati Anderson-Hsiaoovog procjenitelja već samo korigiranog LSDV (Dodatak 2).

Rezultati prezentirani u Dodatku 2, ponovno potvrđuju signifikantnost varijable TRADE u utjecaju na gospodarski rast, što upućuje na zaključak da je veći stupanj gospodarske otvorenosti zemlje pozitivno koreliran s gospodarskim rastom. Sukladno očekivanjima državna potrošnja (varijabla GOVERNMENT) je negativno povezana s gospodarskim rastom. Kao i u modelu s fiksnim efektima INFLACIJACPI se pokazala u signifikantnoj vezi s gospodarskim rastom, ali je koeficijent ponovno mali, te se zbog toga ova varijabla može zanemariti. Najveću vrijednost (oko 0.70) je pokazao koeficijent uz lagiranu vrijednost varijable DLOGGDP, što upućuje na zaključak da veća stopa gospodarskog rasta u protekloj godini ( $t-1$ ) dovodi do veće stope rasta dohotka ( $u$   $t$ ) u prosjeku za 0.7 postotnih bodova. Indikatori financijske integracije se niti u jednom od rezultata nisu pokazali signifikantnim.

## 6. ZAKLJUČAK

Učinci financijske integracije na gospodarski rast su u posljednjih petnaestak godina predmet istraživanja brojnih ekonomista. Unatoč ogromnom broju radova koji su se, vezano uz navedenu tematiku pojavili u spomenutom razdoblju, oni nisu u potpunosti rasvijetljeni. Premda ekonomska teorija ističe da financijska integracija kroz različite kanale može utjecati na gospodarski rast, također se smatra da može imati i nepovoljne efekte, kao što su financijske zaraze i makroekonomska nestabilnost koji se opet nepovoljno odražavaju na gospodarski rast. Upravo stoga što teorija ne daje jasan odgovor glede učinka financijske integracije na gospodarski rast, važno je istaknuti i rezultate odabranih empirijskih istraživanja. Prema njima se ne može sa sigurnošću tvrditi da financijska integracija utječe na gospodarski rast, mada neki autori upozoravaju na oprez prilikom interpretacije rezultata imajući u vidu mogućnost pogrešnog mjerenja stupnja financijske integracije. U skladu s rezultatima pojedinih autora može se zaključiti da učinci financijske liberalizacije ovise o stupnju gospodarskog i financijskog razvoja, te kvaliteti institucija same zemlje.

Imajući to u vidu čini se da je testiranje postavljene hipoteze u radu koja glasi da veća financijska integracija pridonosi gospodarskom rastu posttranzicijskih zemalja, besmisleno. Budući da su imale zastarjelu kapitalnu opremu, ove su zemlje posezale za investicijama kako bi što prije dostigle dotadašnje članice Europske unije prema stupnju razvijenosti za što im je trebao pristup svjetskim financijskim tokovima. To bi značilo da postoji mogućnost da se financijska integracija ipak pozitivno odrazi na rast ovih zemalja. Pritom ih je dio već postao članicama ili su u procesu pridruživanja Europskoj uniji, pa su morale izgrađivati i potrebne institucije koje su im mogle pomoći da imaju veće koristi od financijske integracije. U modelu je primijenjena panel analiza.

Kada se primijeni panel model s fiksnim efektima (bez vremenskih), dolazi se do zaključka da na stopu rasta utječu kamatna marža i trgovina, i to s očekivanim predznacima. Državna je potrošnja signifikantna na razini od 10% u tri slučaja. Inflacija je signifikantna u svim slučajevima, ali se zbog jako malog koeficijenta učinak ove varijable može zanemariti.

Dodaju li se vremenski efekti u model s fiksnim efektima, signifikantnom ostaje varijabla kamatna marža s očekivanim negativnim predznakom. Inflacija je ponovno signifikantna u svim slučajevima, ali se njen učinak ponovno može zanemariti zbog jako malog koeficijenta. Državna potrošnja je značajna samo u dva slučaja, dok se trgovina više ni u kom slučaju nije pokazala signifikantnom.



Dosadašnja analiza nije uzela u obzir mogućnost da stopa rasta dohotka može biti AR(1) proces, što ukazuje na mogućnost da su procjene dobivene spomenutim modelom, pristrane i nekonzistentne. Stoga se prišlo primjeni dinamičkog panel modela s vremenskim efektima. Pokazalo se da na stopu rasta signifikantno utječu stopa rasta iz prethodnog razdoblja, trgovina, te državna potrošnja. Prve dvije varijable imaju pozitivan, a treća negativan efekt. Kamatna se marža više nije pokazala signifikantnom.

Primijenjena analiza, naravno, ima i svoja ograničenja. OLS procjenitelj kakav se koristi u fiksnim efektima je konzistentan ako je šira ili individualna ili vremenska dimenzija. Korigirani LSDV procjenitelj imaće poželjna svojstva pri manjoj individualnoj komponenti, što znači i potrebu za širom vremenskom dimenzijom panela. Kako su podaci u panel analizi na godišnjoj razini, individualna komponenta u modelu s fiksnim efektima se povećala uključivanjem zemalja bivšeg SSSR-a u analizu. S obzirom na to da to nisu zemlje koje su u procesu pridruživanja EU, pa je moguć njihov manji stupanj integracije s članicama EU, a imaju i niži stupanj institucionalnog razvoja, postoji mogućnost da je njihovo uključivanje utjecalo na same zaključke istraživanja. Zbog podataka na godišnjoj razini, orijentacija samo na zemlje koje su članice EU ili su u procesu pridruživanja EU bi znatno smanjila broj opažanja. Imajući u vidu mišljenje Hermesa i Lensinka (2008.), koji ne podupiru analizu utjecaja financijske integracije na seriji od petnaestak vremenskih opažanja, šire vremenske serije u budućnosti će omogućiti istraživanja koja će više rasvijetliti ovu vezu. Također je na rezultate mogla utjecati i primjena agregiranih podataka u samoj analizi. Stoga dobivene rezultate kojima se postavljena hipoteza ipak ne može prihvatiti, valja uzeti s oprezom.

## LITERATURA:

1. Acocella, N. (2005.), Počela ekonomske politike. MATE d.o.o., Zagreb, prijevod.
2. Agénor, P.-R. (2003), Benefits and Costs of International Financial Integration: Theory and Facts. *The World Economy*, 26 (8), str. 1089. - 1118.
3. Alfaro, L., Kalemli-Özcan, S., Volosovich, V. (2007), Capital Flows in a Globalised World: The Role of Policies and Institutions. U S. Edwards(ed), *Capital Controls and Capital Flows in Emerging Economies: Policies, Practices, and Consequences* (str. 19. - 68.). Chicago: University of Chicago Press.
4. Alfaro, L., Kalemli-Özcan, S., Volosovich, V. (2008), Why Doesn't Capital Flow from Rich to Poor Countries? An Empirical Investigation. *The Review of Economics and Statistics*, 90 (2), str. 347. - 368.
5. Anderson, T. W., Hsiao, C. (1981), Estimation of dynamic models with error components. *Journal of the American Statistical Association*, 76 (375) str. 589. - 606.
6. Anderson, T. W., Hsiao, C. (1983), Formulation and estimation of dynamic models using panel data. *Journal of Econometrics*, 18 (1) str. 570. - 606.
7. Apergis, N., Lyrroudi, K., Vamvakidis, A. (2008), The relationship between foreign direct investment and economic growth: evidence from transition countries. *Transition Studies Review*, 15 (1) str. 37. - 51.

8. Arellano, M., Bond, S. (1991), Some Tests of specification for Panel Data: Monte Carlo Evidence and Application to Employment Equations, *Review of Economic Studies*, 58(2), str. 277. - 297.
9. Arfaoui, M., Abaoub, E. (2010.), On the determinants of international financial integration in the global business area. *Journal of Applied Economic Sciences (JAES)*, 5 (13), str. 153. - 172.
10. Arribas, I., Pérez, F., Tortosa-Ausina, E. (2009), The determinants of international financial integration revisited: the role of networks and geographic neutrality. *MPRA Paper* (18717), str. 1. - 44.
11. Asteriou, D., Dassiou, X., Glycopantis, D. (2005), FDI and growth: Evidence from a Panel of European Transition Countries. *Spydai*, 55 (1), str. 9. - 30.
12. Bačić, K., Račić, D., Ahec-Šonje, A. (2004.), The effects of FDI on recipient countries in Central and Eastern Europe. *Privredna kretanja i ekonomska politika*, 14 (100), str. 59. - 96.
13. Baltagi, B. (2005), *Economic Analysis of Panel Data* (Svez. 3rd Edition). Wiley.
14. Baltagi, B. (ožujak 2000), Nonstationary Panels, Cointegrations in Panels and Dynamic Panels: A Survey. *Center for Policy Research Working Paper No 16*.
15. Beck, T., Demirgüç-Kunt, A., Levine, R. (2009), "A New Database on Financial Development and Structure", *World Bank Economic Review* 14, str. 597. - 605.
16. Blundell, R., Bond, S. (1998), Initial conditions and moment restrictions in dynamic panel data models. *Journal of econometrics*, 87 (1), str. 115. - 143.
17. Bonfiglioli, A. (2007), Financial Integration, Productivity and Capital Accumulation. *UFAE and IAE Working Papers*, 680.07, str. 1. - 41.
18. Bonfiglioli, A. (2005), *How Does Financial Liberalization Affect Economic Growth*. Dohvaćeno iz <http://www.iies.su.se/publications/seminarpapers/736.pdf>.
19. Bosworth, B., Collins, S. (1999), Capital Flows to Developing Economies: Implications for Saving and Investment. *Brookings Papers on Economic Activity*, 1999 (1), str. 143. - 169.
20. Bruno, G. (2005b), Approximating the bias of the LSDV estimator for dynamic unbalanced panel data models. *Economics Letters*, 87 (3), str. 361. - 366.
21. Bruno, G. (2005a), Estimation and inference in dynamic unbalanced panel-data models with a small number of individuals. *The Stata Journal*, 5 (4) , str. 473. - 500.
22. Collins, S. (2007), Comments on "Financial Globalization, Growth, and Volatility in Developing Countries", by Eswar Prasad, Kenneth Rogoff, Shang-Jin Wei, and M. Ayhan Kose,". U A. Harrison, *Globalization and Poverty* (str. 510. - 516.). Chicago: University of Chicago Press.
23. Edison, H., Levine, R., Ricci, L., Sløk, T. (2002), International financial integration and economic growth. *Journal of International Money and Finance*, 21 (6), str. 749. - 776.
24. Edwards, S. (2001), Capital Flows and Economic Performance: Are Emerging Economies Different. *NBER Working Paper* , no. 8076.

25. Eichengreen, B. (2001), Capital Account Liberalization: What do Cross-Country Studies Tell Us? *World Bank Economic Review*, 15 (3), str. 341. – 365.
26. Fratzcher, M., Bussiere, M. (2004), Financial Openness and Growth: Short-run Gain, Long-run Pain? *ECB, Working Paper series, No 348*, str. 1. - 43.
27. Galliani, S., González-Rozada, M. (2002), Inference and estimation in small sample dynamic panel data models. *CIF Working Papers* [http://www.utdt.edu/Upload/CIF\\_wp/wpcif-022002.pdf](http://www.utdt.edu/Upload/CIF_wp/wpcif-022002.pdf).
28. Gardó, S., Martin, R. (2010), The Impact of the Global Economic and Financial Crisis on Central, Eastern and South-Eastern Europe: A Stock Taking Exercise". *Occasional Paper Series* (114), str. 1. - 67.
29. Garita, G. (2009), How Does Financial Openness Affect Economic Growth and its Components? *MPRA Paper* (20099), str. 1. - 33.
30. Greene, W. (2000), *Econometric Analysis*. New York: Prentice Hall.
31. Hermes, N., Lensink, R. (2008), Does Financial Liberalization Influence Saving, Investment and Economic Growth? Evidence from 25 Emerging Market Economies, 1973. - 1996. U B. Guha-Khasnobis, G. Mavrotas (eds.), *Financial Development, Institutions, Growth and Poverty Reduction* (str. 164. - 189.). Basingstoke: Palgrave MacMillan.
32. Judson, R., Owen, A. (1996), Estimating Dynamic Panel Data Models: A Practical Guide for Macroeconomists. *Federal Reserve Board of Governors*, str. 1. - 21.
33. Kiviet, J. (1995), On bias, inconsistency and efficiency of various estimators in dynamic panel data models. *Journal of Econometrics*, 68 (1), str. 53. - 78.
34. Klein, M., Olivei, G. (2008), Capital Account Liberalization, Financial Depth, and Economic Growth. *Journal of International Money and Finance*, 27 (6), str. 861. - 875.
35. Kose, M. A., Prasad, E., Rogoff, K., Wei, S.-J. (2009), Financial Globalization: A Reappraisal. *IMF Staff Papers*, 56 (1), str. 8. - 62.
36. Kraay, A. (1998), In Search of the Macroeconomic Effects of Capital Account. *unpublished World Bank*.
37. Lane, P., Milesi-Ferretti, G. M. (2007), The External wealth of nations mark II. Revised and extended estimates of foreign assets and liabilities, 1970 - 2004. *Journal of International Economics*, 73 (2), str. 223. - 250.
38. Lane, R., Milesi-Ferretti, G. (August 2009), "Updated and extended version of the External Wealth of Nations Mark II database developed by (Lane, Milesi-Ferretti, 2007).
39. Levine, R. (2001), International Financial Liberalization and Economic Growth. *Review of International Economics*, 9 (4), str. 688. - 702.
40. Lucas, R. (1990), Why Doesn't Capital Flow from Rich to Poor Countries. *American Economic Review*, 80 (2), str. 92. - 96.
41. Maddala, G. S. (2001), *Introduction to Econometrics* (Svez. 3rd Edition). Wiley.
42. McLean, B., Shrestha, S. (2002), International Financial Liberalisation and Economic Growth. *Reserve Bank of Australia Research Discussion Paper* (2002-02), str. 1. - 27.

43. Mencinger, J. (2003), Does Foreign Direct Investment Always Enhance Economic Growth? *Kyklos*, 56 (4), str. 491. - 508.
44. Nickell, S. (1981), Biases in Dynamic Models with Fixed Effects. *Econometrica* 49, str. 1417. - 1426.
45. Mishkin, F. (2004), The Economics of Money, Banking and Financial Markets, 7th Edition, Pearson Addison Wesley.
46. Prasad, E., Rogoff, K., Wei, S.-J., Kose, M. A. (2003), Effects of Financial Globalization on Developing Countries: Some Empirical Evidence. *IMF Occasional Paper*, 220.
47. Quinn, D. (2003), Capital Account Liberalization and Financial Globalization 1890 - 1999: A Synoptic View. *International Journal of Finance and Economics*, 8 (3) str. 189. - 204.
48. Quinn, D. (1997), The Correlates of Changes in International Financial Regulation. *American Political Science Review*, 91 (3), str. 531. - 551.
49. Rodrik, D. (1998), Who Needs Capital-Account Convertibility? U S. Fischer, R. Cooper, R. Dornbusch, P. Garber, C. Massad, J. Polak, i dr., *Should the IMF Pursue Capital Account Convertibility? - Essays in International Finance No 207* (str. 55. - 65.).
50. Schmukler, S. (2004), Financial Globalization: Gain and Pain for Developing Countries. *Federal Reserve Bank of Atlanta Economic Review*, Q2 2004, str. 39. - 66.
51. Schreiber, S. (2008), The Hausman Test Statistic can be Negative even Asymptotically. *Journal of Economics and Statistics*, 228 (4), str. 394. - 405.
52. Stiglitz, J. E. (2004), Capital Market Liberalization, Globalization and the IMF. *Oxford Review of Economic Policy*, 20 (1), str. 57. - 71.
53. Stiglitz, J. E., Weiss, A. (1981), Credit Rationing in Markets With Imperfect Information. *American Economic Review*, 71, str. 393. - 410.
54. Šimurina, J. (2006.), Influence of FDI on Growth in Central and Eastern Europe. U R. Jovančević, Ž. Šević (ed.), *Foreign Direct Investment Policies in South East Europe* (str. 99. - 113.). Greenwich University Press – Ekonomski fakultet Zagreb.
55. Vo, X. V., Daly, K. J. (2007), The determinants of international financial integration. *Global Finance Journal*, 18 (1), str. 228. - 250.
56. Wooldridge, J. (2002), *Econometric Analysis of Cross-Section and Panel Data*. MIT Press.
57. Wooldridge, J. (2003), *Introductory Econometrics: A Modern Approach*. Thomson.
58. World Bank. (2009), *World Development Indicators*. World Bank.



### DODATAK 1. ISPIS REZULTATA MODELA S DVOSTRUKIM FIKSNIM EFEKTIMA

<b>Model s dvostrukim fiksnim efektima</b>					
Zavisna varijabla: DLOGGDP					
Kontrolna varijabla	IFIGDP	GEQGDP	IFITRADE	GEQTRADE	EQSHARE
NIM	-0.0394 (0.00950)**	-0.03744 (0.00925)**	-0.0394 (0.00950)**	-0.03744 (0.00925)**	-0.0335 (0.00984)**
INFLACIJACPI	-0.00015 (0.00007)*	-0.00015 (0.00006)*	-0.00015 (0.00007)*	-0.00015 (0.00006)*	-0.00016 (0.00006)*
GOVERNMENT	-0.04419 (0.02272)+	-0.02957 (0.02243)	-0.04419 (0.02272)+	-0.02957 (0.02243)	-0.02709 (0.02483)
TRADE	0.012 (0.03057)	0.01796 (0.02983)	-0.00741 (0.03035)	-0.00345 (0.02876)	0.01146 (0.02908)
IFIGDP	-0.01941 (0.01431)				
GDP_1	-0.04517 (0.08391)	-0.0686 (0.08223)	-0.04517 (0.08391)	-0.0686 (0.08223)	-0.05007 (0.08532)
IFITRADE			-0.01941 (0.01431)		
GEQTRADE				-0.02141 (0.00845)*	
EQSHARE					-0.01312 (0.01029)
Konstanta	0.88675 (1.94426)	1.52502 (1.96705)	0.88675 (1.94426)	1.52502 (1.96705)	1.1045 (2.04039)
Opažanja	287	287	287	287	287
Broj grupa	23	23	23	23	23
R <sup>2</sup>	0.56	0.58	0.56	0.58	0.56
Robustne standardne pogreške u zagradama					
+ signifikantno at 10%; * signifikantno at 5%; ** signifikantno at 1%					

NAPOMENA: Vremenski su efekti izostavljeni zbog štednje prostora.

## DODATAK 2. REZULTATI KORIGIRANOG LSDV PROCJENITELJA

<b>Korigirani LSDV procjenitelj s vremenskim efektima za dinamički panel</b>					
Zavisna varijabla: DLOGGDP					
Kontrolna varijabla	IFIGDP	GEQGDP	IFITRADE	GEQTRADE	EQSHARE
L.DLOGGDP	0.71411 (0.17796)**	0.69243 (0.13507)**	0.71411 (0.17796)**	0.69243 (0.13507)**	0.6885 (0.12922)**
NIM	-0.01257 (0.01149)	-0.00895 (0.01036)	-0.01257 (0.01149)	-0.00895 (0.01036)	-0.00822 (0.00989)
INFLACIJACPI	-0.00013 (0.00003)**	-0.00014 (0.00002)**	-0.00013 (0.00003)**	-0.00014 (0.00002)**	-0.00013 (0.00002)**
GOVERNMENT	-0.04249 (0.01822)*	-0.03249 (0.01744)+	-0.04249 (0.01822)*	-0.03249 (0.01744)+	-0.03603 (0.01725)*
TRADE	0.05193 (0.02739)+	0.0503 (0.02310)*	0.03451 (0.02821)	0.04574 (0.02432)+	0.04711 (0.02332)*
IFIGDP	-0.01742 (0.01258)				
GEQGDP		-0.00456 (0.00669)			
IFITRADE			-0.01742 (0.01258)		
GEQTRADE				-0.00456 (0.00669)	
GEQSHARE					-0.00242 (0.00693)
Opažanja	286	286	286	286	286
Broj grupa	23	23	23	23	23
<i>(Bootstrapped)</i> standardne pogreške u zagradama					
+ signifikantno pri 10%; * signifikantno pri 5%; ** signifikantno pri 1%					

NAPOMENA: Vremenski su efekti izostavljeni zbog štednje prostora. Varijabla L.DLOGGDP označava lagiranu vrijednost varijable DLOGGDP.